

教師無し学習を用いた動作リターゲットによる ヒューマノイドテレオペレーション

○八木 聡明（京大） 多田 充徳（産総研） 内部 英治（ATR）
叶賀 卓（産総研） 松原 崇充（奈良先端大） 森本 淳（京大・ATR）

本研究では CycleGAN ベースのオンラインモーションリターゲットを用いたヒューマノイドロボットのテレオペレーション手法を提案する。提案手法は学習過程において人とロボット間でペア付けされた動作のデータセットが不要である。これにより、ロボティクスの知識がないユーザーでもロボットをダイレクトティーチングするなどして直感的に学習データを収集し、事前設定不要で遠隔操作用のコントローラーを構築できる。実験では、1.6 時間分の人の動作と 2.2 時間分の上半身型ロボットの動作データを収集してネットワークの学習を行い、ボクシングやバスケットボールシュート動作などの人の動作をロボットにリターゲットできることを確かめた。また、全身を使った動作による物体の持ち上げ・移動タスクを遠隔操作で実施し、テレオペレーションコントローラーとしての有効性を確かめた。

1. はじめに

人がロボットを遠隔操作するテレオペレーションでは、計測した人の動作をロボットの動作に変換するためのマッピングを導出する必要がある。その手法の一つとして、CG アニメーションの分野などで広く利用されているモーションリターゲット（モーションリターゲットイング）が挙げられる。例えば、操作者の体にマーカーを取り付け、そのマーカーの位置をモーションキャプチャシステムで計測することで、対応するロボット側の位置の誤差を最小化するように関節角度を計算する。このマーカーの位置による対応付け設定には専門的な知識が必要で、あらかじめロボットが振る舞う動作を想定してこの手動設定を行うため、予期しない動作が入力された場合にモーションリターゲットが破綻しやすい。

大規模な人の動作データセットが入手できるようになったことに伴い、データ駆動型のモーションリターゲット手法も発達してきている。特に、ニューラルネットワークをベースとした手法では、人とロボットの高精度なモーションリターゲットに成功している。これらの手法の多くは、上述した手作業によるの身体位置の対応付け作業を必要とせず、これまで以上に多様な動作に対してモーションリターゲットを実現する。その一方で、学習データのクリーニングや対応する動作のペア付けなどのデータの準備に多大な時間と労力が必要である。この事前処理に対する解決策として、CG アニメーションの分野ではデータセットのペア付けを必要としないモーションリターゲットが提案されている [1, 2]。特に、Aberman らは CycleGAN のネットワークアーキテクチャ [3] を使用した高精度なモーションリターゲット手法を報告している [4]。

ロボティクスの分野においても、人からロボットへのモーションリターゲットの文脈でデータのペア付けを必要としない教師無し学習による手法が提案されている。例えば、ImitationNet は深層距離学習を利用して人の動作から人らしいロボットの動作を生成する [5]。CycleAutoencoder は人とロボットの動作をエンコードおよびデコードする 2 対のオートエンコーダーで交互に動作を変換することでモーションリターゲットングを学習する [6]。しかし、これらの先行研究では出力される動作はロボットの腕のみに限定されている。Choi らは腕




図1 モーションリターゲットの概要

だけでなくヒューマノイドの上半身全体のモーションリターゲットを実現したものの、半教師あり学習であり依然としてデータのペア付けを必要とする [7]。

本研究では、CG アニメーションの分野で高精度な全身のモーションリターゲットを実現した Aberman らの手法 [4] を拡張し、人からヒューマノイドへのモーションリターゲットをオンラインで実行するテレオペレーションコントローラーを提案する。本手法は図 1 に示すように、多層のグラフ畳み込みネットワークを介して人の動作をより簡易な骨格で表現し直し、そこからロボットの骨格での動作の表現に復元していく。特に、ネットワークの学習において、損失関数にロボットの関節の向きを考慮させ、ロボットの姿勢として人と実機の間中間的な表現を採用することで先行研究よりも高精度なリターゲットが可能であることを実験的に確かめた。また、上半身型ヒューマノイドを用いた実機実験では腕と腰関節を協調させた物体の持ち上げ・移動タスクをテレオペレーションで実施した。

2. 教師無し学習を用いた動作リターゲット

図 2 にネットワークの概要を示す。人とロボットのデータを扱う 2 対のオートエンコーダーと識別器で構成される。人側の添字を h 、ロボット側の添字を r とすると、ネットワークはエンコーダー E_h と E_r 、デコーダー D_h と D_r 、識別器 C_h と C_r で構成される。




図2 ネットワークの概要




図3 多層エンコーダーのネットワーク構造

人のデータセット D_h からサンプリングされるデータを x_h , エンコーダー E_h から出力される潜在空間での動作 z_h , デコーダー D_h を通して再構成された人データを $\hat{x}_{h \rightarrow h}$ とする. 添字 r としてロボットも同様に定義する. そして, 人の動作をリターゲットして得られたロボットの動作を $\hat{x}_{h \rightarrow r}$ とする. すなわち, $\hat{x}_{h \rightarrow r} = D_r(z_h)$, $z_h = E_h(x_h)$ である.

図3にエンコーダー E_h , E_r を構成する多層エンコーダーの1層を示す. 図1に示すように各層のエンコーダーでは, 入力された姿勢(骨格)の関節数を半減させた姿勢とそれに対応した動作を出力する. 姿勢と動作を並列して処理することでネットワークは姿勢に依らない共通の潜在動作表現を獲得できる. また, デコーダーおよび識別器も同様の構造である.

図3の上段では姿勢のデータを扱い, 全結合層(FCL1)・活性化関数(Leaky ReLU)・グラフプーリングから成る. 下段では動作のデータを扱い, グラフ畳み込みを行った上で上段の姿勢の情報を全結合層(FCL2)を通して加算し, 活性化関数(Leaky ReLU)・グラフプーリングが行われる. なお, グラフ畳み込み・プーリングの実装は先行研究[4]を参考にした.

ネットワークの学習に用いた損失関数を示す. 再構成損失 $\mathcal{L}_{\text{rec}}^{1-3}$ は, 式1, 2, 3で表される. 式1は全関節におけるクォータニオンの平均二乗誤差を計算する. 式2は順運動学 f を用いて全関節の位置の平均二乗誤差を計算する. なお, 頭の高さを1.0として正規化している. 式3はロボット側のネットワークのみに適用される損失関数で, 実際のロボットが動かせる関節方向のみを用いて計算する順運動学 f_r と, 関節の可動方向の制約を考慮しない順運動学 f による全関節の位置の平均二乗誤差を




図4 テレオペレーションシステムの概要

計算する.

$$\mathcal{L}_{\text{rec}}^1 = \mathbb{E}_{x_h \sim D_h} [\|\hat{x}_{h \rightarrow h} - x_h\|^2] \quad (1)$$

$$\mathcal{L}_{\text{rec}}^2 = \mathbb{E}_{x_h \sim D_h} [\|f(\hat{x}_{h \rightarrow h}) - f(x_h)\|^2] \quad (2)$$

$$\mathcal{L}_{\text{rec}}^3 = \mathbb{E}_{x_r \sim D_r} [\|f_r(\hat{x}_{r \rightarrow r}) - f(\hat{x}_{r \rightarrow r})\|^2] \quad (3)$$

サイクル一貫性損失 $\mathcal{L}_{\text{ltc}}$ は式4で計算される. 人とロボットで共通の潜在空間を獲得させることを促進する. なお, $\|\cdot\|_1$ は L_1 ノルムである.

$$\mathcal{L}_{\text{ltc}} = \mathbb{E}_{x_h \sim D_h} [\|E_r(\hat{x}_{h \rightarrow r}) - E_h(x_h)\|_1] \quad (4)$$

敵対性損失 $\mathcal{L}_{\text{adv}}$ は式5で表される. 本損失はLSGANの最小二乗損失である. 実際の動作 x_r を本物, リターゲットされた動作 $\hat{x}_{h \rightarrow r}$ を偽として, C_r が識別を行う.

$$\mathcal{L}_{\text{adv}} = \mathbb{E}_{x_h \sim D_h} [\|C_r(\hat{x}_{h \rightarrow r})\|^2] + \mathbb{E}_{x_r \sim D_r} [\|1 - C_r(x_r)\|^2] \quad (5)$$

エンドエフェクター損失 $\mathcal{L}_{\text{ee}}$ は式6で表される. リターゲットされた動作の速度の不一致にペナルティを課す. ここで, Δf_{ee} は前フレームからの頭と両手のエンドエフェクターの位置の差分を計算している. Δt はサンプリング時間である.

$$\mathcal{L}_{\text{ee}} = \mathbb{E}_{x_h \sim D_h} \left[\left\| \frac{\Delta f_{\text{ee}}(\hat{x}_{h \rightarrow r})}{\Delta t} - \frac{\Delta f_{\text{ee}}(x_h)}{\Delta t} \right\|^2 \right] \quad (6)$$

本研究に用いた損失関数 $\mathcal{L}$ は次の通りである: $\mathcal{L} = 5.0\mathcal{L}_{\text{rec}}^1 + 2000.0\mathcal{L}_{\text{rec}}^2 + 1000.0\mathcal{L}_{\text{rec}}^3 + 5.0\mathcal{L}_{\text{ltc}} + 3.5\mathcal{L}_{\text{adv}} + 225.0\mathcal{L}_{\text{ee}}$.

3. テレオペレーションシステム

図4に, テレオペレーションシステムの構成を示す. モーションキャプチャシステムを用いて, 操作者の関節クォータニオンを50Hzで取得する. 姿勢は初回のキャリブレーション時に取得する. 事前に学習済みのネットワークを用いて遠隔操作PCがロボットの動作をモーションリターゲットによって生成する. その結果を, 25Hzでロボットの目標関節角度として制御PCに送信する.

学習データの収集について説明する. 人の動作データはモーションキャプチャシステム Mocopi (ソニー製) を用いて収集した. データ収集に特定のルールは設定せず, オフィス作業やスポーツ, ダンスなど多様な種類の動作を用意した. ネットワークでは姿勢と動作を並列で処理するが, 姿勢の情報は初回のキャリブレーションで推定された骨格情報を用いた.

ロボットのデータ収集においては, 本研究ではダイレクトティーチングによる動作収集を採用した. テレオペレーションの対象として, 上半身型のヒューマノイドロボット Torobo (東京ロボティクス製) を使用した.




図5 Toroboの関節配置の概要

Toroboは身長84cmの等身大ヒューマノイドで、胴体に2、各腕に7、頭部に2の合計18関節を有する。Toroboに搭載された外力追従モードを用いて3人の教示者が両腕、頭部を指示しながら、人らしい動作を教示し、その際の関節角度のセンサー読み取り値を50Hzのサンプリング周期で記録した。

ロボットの姿勢には、Toroboと人の姿勢の中間の姿勢表現を採用した。これにより、ネットワークが人とロボットの姿勢の対応関係を学習することを促進する。図6に示すように、3種類の位置を関節と定義した。(1) 実際の関節位置(緑の○)、(2) ルート関節と胸部の分岐点(紫の□)、(3) エンドエフェクタ(緑の○)。著者らの経験上、このようにロボットの関節を配置することでネットワークの学習が安定化することが分かっている。また、(2) 胸部の関節は、人側データの姿勢における胸から腕へのリンクの付き方を模倣するように設定する、(3) エンドエフェクタは、実際のエンドエフェクタ先端ではなく、1つ前の親リンクの等しい長さの距離に配置することでネットワークの性能が向上することを確かめている。加えて、順運動学 f_r には、(1)に分類される関節の回転成分のみ用いて計算し、(2)(3)は動かない関節としている。

上記の動作データ収集に加えて、本研究ではKITの双腕物体操作のデータセット[8]を追加し、389,157フレーム(約2.2時間)のTorobo動作データと281,155フレーム(約1.6時間)の人動作データでネットワークを学習した。14,000エポックの学習を行い、学習に要した時間は約10時間(NVIDIA GeForce RTX 4090 GPU, Intel Core i9-13900 CPU)であった。また、学習データに含まれていない6380フレーム分、10種類の人の動作を評価用として別途用意した。

4. 結果

図6に代表的な結果(a)ボクシング動作(フレーム間隔160ms)と(b)バスケットボールシュート動作(フレーム間隔120ms)を示す。右に向かって時系列順、元の人の動作を1行目の黒色のイラストで示す。リターゲットで得られたロボットの動作の良し悪しは評価する人の主観に依存し、1つの動作を正解として決めるのは適切でない。そこで本研究では、リターゲットされたロボットの動作を再び人の動作にリターゲットし、元の動作との誤差を定量的な評価指標として用いる。まず、10種類の人の動作をToroboの動作にリターゲットし、得られた動作を再び人の動作にリターゲットする。全動作における関節の平均位置誤差は14.7mmであった。なお、座標系の原点であるルート関節は計算に含めていない。

図6の2行目の青色のイラストに先行研究[4]の手法

を用いてリターゲットしたToroboの動作を示す。ネットワークの学習は同様に14,000エポックである。Toroboは先行研究で扱ったCGアニメーションの骨格と比較して多くの腕関節を持っており、リターゲットが失敗していることが分かる。先ほどと同様に元の人の動作とリターゲットを2回行って再構成した動作の関節位置の平均二乗誤差を計算すると、提案手法の倍以上である32.3mmであった。

図7にToroboをテレオペレーションした様子を示す。1.3秒の間隔で右に向かって時系列順に表示している。操作者はToroboの背後に立ち、視覚的なフィードバックを得る。このタスクでは、Toroboを遠隔操作して右側の机から箱を持ち上げて左側の机に移す。箱はToroboの両腕の作業空間外に置かれており、腰を前傾に倒しつつ腕を伸ばして持ち上げなければならない。1から5フレーム目では箱を拾い上げるためToroboは腰をひねりながら前屈みの姿勢を取っている。6から8フレーム目でToroboは箱を持ち上げて隣の机に置く。その後、9フレーム以降では元の姿勢に戻っている。


5. まとめ

本研究では人からロボットへのモーションリターゲットを利用したテレオペレーションシステムを提案した。本手法は、学習データのラベル付けが不要で、事前設定作業の負担を軽減したユーザーフレンドリーなシステムである。実験を通してボクシングやバスケットボールシュートなどの動作を上半身型ヒューマノイドにリターゲットできることを確かめた。また、得られたロボットの動作を再度人の動作にリターゲットし、全関節の平均位置誤差を求めたところ、提案手法14.7mmで従来手法32.3mmを超える性能であった。さらに、実際のテレオペレーションで箱の持ち上げタスクを実施し、システムの有効性を確かめた。


謝辞 本研究はJST未来社会創造事業JPMJMI21B1、JSTムーンショット型研究開発事業JPMJMS223B-3、JSPS科研費JP22H03669、JP22K21275の助成を受けて行われた。

参考文献

- [1] R. Villegas, J. Yang, D. Ceylan, and H. Lee: "Neural kinematic networks for unsupervised motion retargeting," in *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 8639–8648, 2018.
- [2] J. Lim, H. J. Chang, and J. Y. Choi: "PMnet: Learning of disentangled pose and movement for unsupervised motion retargeting," in *Proc. British Machine Vision Conference (BMVC)*, 2019.
- [3] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros: "Unpaired image-to-image translation using cycle-consistent adversarial networks," in *Proc. IEEE International Conference on Computer Vision (ICCV)*, pp. 2223–2232, 2017.
- [4] K. Aberman, P. Li, D. Lischinski, O. Sorkine-Hornung, D. Cohen-Or, and B. Chen: "Skeleton-aware networks for deep motion retargeting," *ACM Transactions on Graphics (TOG)*, vol. 39, no. 4, pp. 62–1, 2020.



(a) ボクシング



(b) バスケットボールシュート

図6 人の動作（黒）と先行研究のリターゲット結果（青），提案手法のリターゲット結果（CG）




図7 物体移動のテレオペレーション

- [5] Y. Yan, E. V. Mascaro, and D. Lee: “ImitationNet: Unsupervised human-to-robot motion retargeting via shared latent space,” in *Proc. IEEE-RAS 22nd International Conference on Humanoid Robots (Humanoids)*, pp. 1–8, 2023.
- [6] M. Stanley, L. Tao, and X. Zhang: “Robust motion mapping between human and humanoids using cycleautoencoder,” in *Proc. IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp. 93–98, 2021.
- [7] S. Choi, M. K. Pan, and J. Kim: “Nonparametric motion retargeting for humanoid robots on shared latent space,” in *Robotics: Science and Systems*, 2020.
- [8] F. Krebs, A. Meixner, I. Patzer, and T. Asfour: “The kit bimanual manipulation dataset,” in *Proc. IEEE/RAS International Conference on Humanoid Robots (Humanoids)*, pp. 499–506, 2021.